

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Lea Kapetanović

Zagreb, 2015.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

ZAVRŠNI RAD

Mentor:

Prof. dr.sc. Zoran Kunica

Student:

Lea Kapetanović

Zagreb, 2015.

Zadatak



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za završne ispite studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

ZAVRŠNI ZADATAK

Student: **Lea Kapetanović** Mat. br.: 0035181649

Naslov rada na hrvatskom jeziku: **Primjena *cluster* analize u projektiranju proizvodnih sustava**

Naslov rada na engleskom jeziku: **Application of cluster analysis in the design of manufacturing systems**

Opis zadatka:

Cluster analiza je skupni naziv za niz postupaka koji se primjenjuju za grupiranje objekata na temelju njihovih obilježja. U projektiranju proizvodnih sustava, *cluster* analiza od posebnog je značaja za strukturiranje proizvodnog sustava, gdje se, na temelju proizvodnog programa i tehnologije, nastoje uspostaviti, ako je moguće, nezavisne skupine strojeva unutar kojih će se ekskluzivno obrađivati skupine predmeta rada.

U radu je potrebno:

1. navesti smisao, značaj i postavke *cluster* analize, posebno u projektiranju proizvodnih sustava;
2. istražiti zastupljenost softvera za *cluster* analizu;
3. odabranim softverom, provesti *cluster*iranje te diskutirati dobivene rezultate.

Zadatak zadan:
25. studenog 2014.

Zadatak zadao:

Prof. dr.sc. Zoran Kunica

Rok predaje rada:
1. rok: 26. veljače 2015.
2. rok: 17. rujna 2015.

Predviđeni datumi obrane:
1. rok: 2., 3., i 4. ožujka 2015.
2. rok: 21., 22., i 23. rujna 2015.

Predsjednik Povjerenstva:

Prof. dr.sc. Zoran Kunica

Izjava

Izjavljujem da sam ovaj završni rad izradila samostalno stečenim znanjem tokom studija i navedenom literaturom.

Zahvaljujem mentoru prof. dr.sc. Zoranu Kunici na pomoći pri odabiru teme, savjetima, komentarima i kritikama tokom izrade ovog rada.

Posebno zahvaljujem svojim roditeljima i sestri na pruženoj podršci tokom svih godina studija.

Lea Kapetanović

Sažetak

Klaster analiza ili klasteriranje je tehnika grupiranja skupa objekata na takav način da su međusobno slični objekti grupirani u isti klaster, a objekti koje se međusobno razlikuju se nalaze u različitim klasterima. Potreba za grupiranjem objekata očituje se i u projektiranju proizvodnih sustava gdje se, na temelju proizvodnog programa i tehnologije, nastoje uspostaviti što nezavisnije skupine strojeva (izradbene stanice) unutar kojih će se obrađivati skupine predmeta rada. U radu su opisani smisao i značaj klaster analize, njeni tipovi te prednosti i nedostatci. Nadalje, istražena je zastupljenost softvera za klaster analizu. Najčešće korišteni softveri jesu: SPSS, Statistica, SAS. Također postoji i niz besplatnih softvera kao što su Past i Cluster 3.0. U radu je provedeno klasteriranje sa i bez softvera na primjeru 10 dijelova i 28 strojeva. Za softversko klasteriranje izabran je softver Past, čije je korištenje detaljno opisano, te su na kraju uspoređeni rezultati ručnog i softverskog klasteriranja.

Ključne riječi: klaster analiza, klaster, grupiranje, proizvodni sustavi, grupna tehnologija.

Abstract

Cluster analysis or clustering is the task of grouping a set of objects in such a way that objects in the same group ,called a cluster are more similar in some sense or another to each other than to those in other groups. Need for grouping objects is also present in the design of manufacturing systems, where based on the production programs and technologies, if possible, an independent group of machines (manufacturing cell) is made. This paper describes the meaning and significance of the cluster analysis, its types as well as advantages and disadvantages. Furthermore, it has been explored the representation of software for cluster analysis. The most commonly used software are: SPSS, Statistica, SAS. There are also a number of free software such as Past and the Cluster 3.0. The work was conducted with and without clustering software on the example of 10 parts and 28 machines. For software clustering was selected Past software, whose usage is detailed described and in the end the results of clustering were compared.

Key words: cluster analysis, cluster, clustering, manufacturing systems, group technology.

SADRŽAJ

Zadatak	I
Izjava	II
Sažetak	III
Abstract	IV
Popis slika	VI
Popis tablica	VII
Popis oznaka.....	VIII
1. UVOD.....	1
2. KLASITER ANALIZA	2
2.1. Vrste klaster analize	4
2.1.1. Hijerarhijsko klasteriranje	4
2.1.2. Nehijerarhijsko klasteriranje	7
2.2. Prednosti i nedostaci klaster analize.....	8
3. PRIMJENA KLASITER ANALIZE U PROJEKTIRANJU PROIZVODNIH SUSTAVA .	10
4. KLASITERIRANJE KAO OBLIK TRŽIŠNOG POVEZIVANJA	15
5. SOFTVERI ZA KLASITER ANALIZU.....	17
6. PRIMJER PROVEDBE KLASITER ANALIZE BEZ UPOTREBE SOFTVERA	21
7. SOFTVER PAST	27
8. ZAKLJUČAK	38
9. LITERATURA.....	40

Popis slika

Slika 1. Hijerarhijsko klasteriranje [4]	5
Slika 2. Grupiranje najbližih susjeda [4]	7
Slika 3. Grupiranje dijelova [10]	13
Slika 4. Početni izbornik za analizu [4]	18
Slika 5. Odabir tipa klaster analize [4]	18
Slika 6. Kratki izbornik za klaster analizu [4]	19
Slika 7. Izbor varijabli za analizu [4]	19
Slika 8 Prozor za brzu analizu [4]	20
Slika 9. Dendrogram [4]	20
Slika 10. Glavni izbornik softvera PAST	27
Slika 11. Unos podataka	29
Slika 12. Promjena naziva stupaca i redaka	30
Slika 13. Unos naziva dijelova	31
Slika 14. Unos naziva strojeva	31
Slika 15. Pokretanje softvera za klaster analizu	32
Slika 16. Prozor softvera za klaster analizu	33
Slika 17. Dvosmjerni (<i>two-way</i>) dendrogram	34
Slika 18. Pokretanje <i>k-means</i> metode	35
Slika 19. Unos broja klastera	35
Slika 20. Rezultat <i>k-means</i> metode	36

Popis tablica

Tablica 1. Udaljenosti između jedinica promatranja.....	6
Tablica 2. Grupiranje na osnovi udaljenosti najbližih susjeda.....	6
Tablica 3. Popis dijelova za klaster analizu	21
Tablica 4. Binarna matrica dijelovi-strojevi.....	23
Tablica 5. Skupina dijelova $C_1, m_1 = 4$	24
Tablica 6. Skupina dijelova $C_2, m_2 = 6$	25

Popis oznaka

x_{ik} – vrijednost k -tog obilježja i -toga dijela

x_{jk} – vrijednost k -tog obilježja j -toga dijela

m – broj obilježja (strojeva)

O_{ij} – suma kvadrata odstupanja prema težištu skupine

f_c – funkcija cilja

Δ – razlika, promjena funkcije cilja

n_I – broj objekata skupine iz koje se izdvaja objekt

n_D – broj objekata skupine u koju se dodaje (premješta) objekt

x_{jI}, x_{jD} – aritmetičke sredine vrijednosti obilježja u podskupu iz kojega se izdvaja, odnosno u koji se dodaje objekt

x_j – vrijednost j -toga obilježja objekta koji se premješta

1. UVOD

Klaster analiza je skupno ime za niz matematičko-heurističkih postupaka, kojima je svrha otkrivanje strukture nekog početnog skupa podataka njegovim dekomponiranjem u manje, homogenije podskupove. [1]. Ona klasificira objekte u skupine tako da je svaka skupina homogena s obzirom na određene varijable, a svaka skupina različita od druge s obzirom na te iste varijable. Provođenjem klaster analize dobiju se klasteri.

U projektiranju proizvodnih sustava, klaster analiza od posebnog je značaja za strukturiranje proizvodnog sustava, gdje se, na temelju proizvodnog programa i tehnologije, nastoje uspostaviti, ako je moguće, nezavisne skupine strojeva unutar kojih će se ekskluzivno obrađivati skupine predmeta rada. Za primjenu klaster analize trebaju biti zadani skup dijelova i skup strojeva na kojima se dijelovi obrađuju, pri čemu je za svaki dio poznato na kojim se sve strojevima obrađuje. [1] Kada se govori o strukturiranju proizvodnog sustava podrazumijeva se aktivnost kojoj je cilj najekonomičnije povezati i uskladiti konstituirajuće elemente u vremenu i prostoru. Tako strukturiran proizvodni sustav donosi niz prednosti kao što su: dobro iskorištenje opreme i strojeva, jednostavna raspodjela poslova, kratke transportne udaljenosti, velika preglednost procesa te jednostavno planiranje, vođenje i praćenje izradbe.

Brz razvoj računala, te temeljni značaj klasifikacije kao znanstvene procedure uvjetovali su popularnost ove metode. Postupci klaster analize imaju široku primjenu u mnogim područjima kao što su: istraživanje tržišta, ekonomija, medicina, sociologija, geografija ali i proizvodnja, strojarstvo i slično. Neki od najčešće korištenih softvera za provođenje klaster analize su SPSS, Statistica i SAS. Cilj ovoga rada je navesti smisao, značaj i postavke klaster analize, posebno u projektiranju proizvodnih sustava, istražiti zastupljenost softvera za klaster analizu te odabranim softverom, provesti klasteriranje i diskutirati dobivene rezultate.

2. KLASTER ANALIZA

Klaster analiza predstavlja postupak utvrđivanja relativno homogenih grupa objekata. Ona klasificira objekte u skupine tako da je svaka skupina homogena s obzirom na određene varijable, a svaka skupina različita od druge s obzirom na te iste varijable. Provođenjem klaster analize dobiju se klasteri, a dobivaju se na način da su međusobno najsličniji objekti grupirani u isti klaster. Termin klaster dolazi od engleske riječi *cluster* što označava skupinu istovrsnih stvari, grozd, skupiti u hrpu. Na početku klaster analize grupna pripadnost objekata nije poznata, kao ni konačni broj grupa. Cilj klaster analize jest utvrđivanje homogenih grupa ili klastera. [2]

Predmet klaster analize najčešće su objekti, a ne varijable kao što je to slučaj kod faktorske analize. Osnovna zadaća klaster analize je identifikacija klastera unutar neke populacije objekata. Kako na početku analize nije poznat konačni broj klastera unutar populacije, niti koji objekt pripada kojem klasteru, klastere je potrebno formirati na način da sadrže samo objekte sličnih svojstava. Prema tome, klaster analiza mora odgovoriti na tri temeljna pitanja: kako mjeriti sličnost između objekata, kako formirati klastere te kako utvrditi konačan broj klastera.

Konačan rezultat klaster analize je podjela objekata u klastere u skladu s definiranim ciljevima. U okviru klaster analize postoji veliki broj različitih algoritama koji u načelu odgovaraju na iste probleme. Većina metoda klaster analize predstavlja relativno jednostavne statističke postupke. Različite metode klasterizacije, mogu a često i dovode, do različitih različitih konačnih rješenja. [2] Uz klaster analizu se razvila i specifična terminologija. Jedinice koje se povezuju u klastere obično se nazivaju objekti, entiteti, slučajevi (*cases*). Grupiranje se vrši na osnovi nekih varijabli, atributa, karakteristika ili obilježja. Klaster analizom moguće je pojednostavniti opažanje na način da se svojstva pojedinačnih objekata zamijene općim svojstvom klastera kojem objekti pripadaju.

Klaster analiza polazi za načelom sličnosti. U klaster analizi određuju se mjere sličnosti za sve parove objekata. Na taj se način omogućuje međusobna usporedba svih analiziranih objekata. Koncept udaljenosti (distance) odnosno sličnosti, blizak je mnogim statističkim tehnikama. Mjere distance odnose se na različitost (udaljenost) dva objekta prema nekoj mjerenoj osobini. Mjere sličnosti pokazuju bliskost između dva objekta. Za bliske, srodne objekte mjere udaljenosti su male, dok su mjere sličnosti velike. U klaster analizi ovi koncepti su od iznimne važnosti budući da se na njima zasniva formiranje klastera.

Procedura klaster analize nadalje svrstava slične objekte u klastere. Tri su metode određivanja sličnosti u klaster analizi: mjere korelacije, mjere udaljenosti i mjere udruživanja. Mjere korelacije i mjere udaljenosti operiraju s numeričkim vrijednostima varijabli. Mjere korelacije temelje se na određivanju koeficijenata korelacije između parova objekata izmjerenih na više varijabli. Visoka korelacija označava sličnost među objektima. Mjere udaljenosti su najčešće korištene mjere sličnosti u klaster analizi. Neke od mjera udaljenosti jesu: Euklidova udaljenost, kvadrirana Euklidova udaljenost, Manhattan udaljenost, Mahalanobisova udaljenost. [3] To su zapravo mjere nejednakosti između varijabli čije veće vrijednosti odgovaraju manjoj sličnosti objekata.

Važna osobina klaster analize je činjenica da ona nije metoda strogo statističkog zaključivanja gdje se odabrani uzorak nužno smatra i reprezentativnim za određenu populaciju. Klaster analiza je metoda kojom se određuju strukturalne karakteristike izmjerenih svojstava na strogoj matematičkoj, ali ne i statističkoj utemeljenosti. Prema tome, da bi rezultati klaster analize bili smisleni potrebno je utvrditi pretpostavke koje se odnose na reprezentativnost uzorka. Pouzdanost rezultata klaster analize ovise o reprezentativnosti uzorka. Nakon izbora uzorka i definiranja varijabli uza sve potrebne pretpostavke te uz izračunate matrice sličnosti sljedeći korak u klaster analizi je formiranje klastera. Nakon klaster analize postavlja se pitanje koji broj klastera je od najvećeg značaja. Istraživač sam treba prosuditi, u kontekstu svog istraživanja, koji broj klastera i sa kakvim karakteristikama mu je potreban.

Prvi oblici klaster analize javljaju se početkom prošlog stoljeća, ali se značajnija literatura iz ovog područja razvija od šezdesetih godina.[3] Brzi razvoj računala, te temeljni značaj

klasifikacije kao znanstvene procedure uvjetovali su popularnost ove metode. Postupci klaster analize imaju široku primjenu u mnogim područjima kao što su: istraživanje tržišta, ekonomija, medicina, sociologija, geografija, proizvodnja, strojarstvo i slično. [2]


2.1. Vrste klaster analize

Mnogi algoritmi su korišteni za klaster analizu. Ipak, dva pristupa su se izdvojila kao najbolja, hijerarhijski i nehijerarhijski. [4] Prvi je hijerarhijski pristup koji kao krajnji rezultat ima dendrogram. Dendrogram je grafički prikaz klastera u obliku stabla povezivanja koja može nastati na aglomerativni (gomilajući) ili divizijski (dijeleći) način. Prvo se vrše izračunavanja udaljenosti svih jedinica međusobno, a zatim se grupe formiraju putem tehnika spajanja ili razdvajanja. [2]

Drugi pristup, nehijerarhijski, vrši raščlanjivanje tako da se jedinice mogu kretati iz jedne u drugu grupu u različitim fazama analize. [4] Prvo se pronade točka grupiranja oko koje se nalaze jedinice, na više ili manje proizvoljan način, a zatim se izračunavaju nove točke grupiranja na osnovu prosječne vrijednosti jedinica. Jedinica promatranja se tada pomjera iz jedne u drugu grupu ukoliko je bliža novoizračunatoj točki grupiranja. Proces se odvija iterativno, sve do postizanja stabilnosti za unaprijed zadani broj grupa.

2.1.1. Hijerarhijsko klasteriranje

Hijerarhijski pristupi se nadalje mogu podijeliti na takozvane *aglomerativne* – gomilajuće, te *divisive* tj. dijeleće. Ovi prvi polaze od pojedinih objekata koje povezuju u sve veće klastere, dok drugi polaze od svih objekata udruženih u jedan klaster, te ih zatim dijele do pojedinih objekata. [4]



Slika 1. Hijerarhijsko klasteriranje [4]

Kako je već spomenuto, hijerarhijski pristup kao krajnji rezultat ima dendrogram. Prvo se vrše izračunavanja udaljenosti svih jedinica međusobno, a zatim se grupe formiraju putem tehnika spajanja ili razdvajanja. Tehnika spajanja polazi od toga da je svaka jedinica sama u grupi od jednog člana. Bliske grupe se postepeno spajaju dok se na kraju ne nađu sve jedinice u jednoj grupi. Kod tehnike razdvajanja ide se obrnutim redoslijedom, gdje se od jedne grupe stvaraju dvije, pa od te dvije slijedeće dvije i tako sve dok ne bude svaka jedinica promatranja posebno. To je takozvani dijeleći hijerarhijski pristup koji se, ipak, primjenjuje mnogo rijetko nego aglomerativni. [4]

Gomilajući, hijerarhijski pristup počinje sa matricom udaljenosti između jedinica promatranja. Sve jedinice su u grupama veličine jedan, a zatim se vrši spajanje u veće grupe koje su blizu jedna druge. Postoji više načina kako definirati što je to blizu. Najjednostavniji način je preko najbližih susjeda. Na primjer, u tablici 1 su date udaljenosti između pet jedinica promatranja. Grupiranje je zatim prikazano u tablici 2.


Tablica 1. Udaljenosti između jedinica promatranja

	A	B	C	D	E
A	-				
B	2	-			
C	6	5	-		
D	10	9	4	-	
E	9	8	5	3	-

Tablica 2. Grupiranje na osnovi udaljenosti najbližih susjeda

Udaljenost	Grupe
0	A,B,C,D,E
2	(A,B),C,D,E
3	(A,B),C,(D,E)
4	(A,B),(C,D,E)
5	(A,B,C,D,E)

Dvije grupe se spajaju u jednu ukoliko je neka jedinica promatranja iz jedne grupe najbliža nekoj jedinici iz druge grupe. Pri nultoj udaljenosti sve jedinice su posebno, odnosno ima onoliko grupa koliko ima i jedinica promatranja. Zatim, najmanja udaljenost između dvije jedinice je 2 koja postoji između jedinica promatranja A i B. Zbog toga na nivou udaljenosti od 2 postoje četiri grupe: (A, B), (C), (D) i (E). Slijedeća najmanja udaljenost je 3 i postoje tri grupe: (A, B), (C) i (D, E) itd. Na kraju su sve jedinice u jednoj grupi, na udaljenosti 5. Slika 2. pokazuje dendrogram cluster analize u kojem se vidi kako je vršeno grupiranje.



Slika 2. Grupiranje najbližih susjeda [4]

2.1.2. Nehijerarhijsko klasteriranje

Hijerarhijski pristup gradi klastere korak po korak, sve dok se sve jedinice promatranja ne nađu na dendogramu. Tek nakon toga se pristupa određivanju broja klastera koji imaju značaj za istraživača. Nehijerarhijski pristup ili metoda raščlanjivanja polazi od unaprijed određenog broja klastera koji istraživač sam definira na osnovi iskustva, ranijih analiza ili preporuke statističkog softvera. Nakon toga se pristupa razvrstavanju jedinica promatranja.

Postoje dva načina za razvrstavanje jedinica. Prvi je da se privremeno, na slučajan način, odrede jedinice koje predstavljaju točke grupiranja, pa se na osnovu udaljenosti od tih jedinica sve ostale jedinice smještaju u odgovarajući klaster. Određuje se onoliko točaka grupiranja koliko je unaprijed definirano klastera. Nakon toga računalski program premiješta jedinice iz jednog u drugi klaster da bi bili što homogeniji. Taj postupak se ponavlja nekoliko puta. Pomnije će biti objašnjen jedan od poznatijih pristupa dijeljenja poznat kao *k-means* metoda. Metoda dozvoljava pomicanje članova iz jednog klastera u drugi, što nije dozvoljeno u hijerarhijskim metodama. Prvo se odabere k članova kao početne jedinice. Oni se kasnije zamjenjuju s centroidima (vektorima sredina) klastera. [4]

Postoje različiti načini na koje je moguće odabrati početne točke: na slučajan se način izabere k članova (moguće udaljenih za specificiranu minimalnu udaljenost), izabere se prvih k točaka (opet uz zahtjev minimalne udaljenosti), izabere se k točaka međusobno najudaljenijih i slično. Za metode izbora početnih točaka, broj klastera, k , mora biti zadan. Alternativno,

može biti zadana minimalna udaljenost između početnih točaka i tada se svi članovi koji zadovoljavaju taj kriterij izabiru kao početni. Nakon što su početne točke odabrane, svaka preostala točka u skupu podataka pridružena je klasteru s najbližom početnom točkom (zasnovanom na Euklidskoj udaljenosti). Čim klaster ima više od jednog člana, početna točka klastera zamjenjuje se njegovim centroidom. Nakon što su svi članovi pridruženi klasterima za svaki se član provjerava je li bliži centroidu nekog drugog klastera nego centroidu vlastitog klastera. Ako jest, premješta se u novi klaster, a centroid klastera se ponovo preračunava. Postupak se nastavlja sve dok nova poboljšanja više nisu moguća.

Metoda *k-means* može se koristiti kao moguća potvrda hijerarhijskog postupka. Prvo se klasteriraju članovi hijerarhijskom metodom, a zatim se centriodi klastera koriste kao početne točke za *k-means* pristup, koji dozvoljava realokaciju točaka iz jednog klastera u drugi. [2]

2.2. Prednosti i nedostaci klaster analize

Klaster analiza je metoda koja se može primjeniti u mnogo različitih istraživanja i područja djelovanja što je velika prednost ove metode. Često se istraživači susreću s velikim brojem opservacija koje je nemoguće interpretirati, ukoliko nisu grupirane u klastere. Prema tome, glavna prednost klaster analize je redukcija podataka i svođenje karakteristika populacije na karakteristike reprezentativnih skupina uz minimalan gubitak informacija. Klaster analizom moguće je pojednostavniti opažanje na način da se svojstva pojedinačnih objekata zamijene općim svojstvom klastera kojem objekti pripadaju. Uzimajući u obzir osnovne mogućnosti klaster analize može se zaključiti da je ova metoda korisna za razvoj novih i provjeru postojećih hipoteza.

Glavni je nedostatak klaster analize izostanak statističke osnove te se na temelju ove metode teško i uz veliku dozu subjektivne procjene istraživača može zaključivati o populaciji na temelju analiziranog uzorka. Nadalje, rješenja klaster analize nisu jedinstvena već uvelike ovise o primjeni različitih elemenata analitičke procedure (naprimjer hijerarhijska ili nehijerarhijska metoda, različiti algoritmi iste metode i slično). Klaster analiza će uvijek kreirati klastere neovisno o smislenosti postojanja bilo kakve strukture među varijablama. Krajnji rezultat klaster analize u potpunosti ovisi o varijablama koje su korištene kao osnova

za mjerenje sličnosti pa istraživač mora voditi računa o procjeni utjecaja svake odluke prilikom izbora varijabli. Naposljetku, konačan broj klastera kao rješenja klaster analize ovisi u velikoj mjeri o subjektivnim odlukama istraživača.

3. PRIMJENA KLASER ANALIZE U PROJEKTIRANJU PROIZVODNIH SUSTAVA

Danas, proizvodna poduzeća se nalaze u nepredvidljivom i konkurentnom okruženju. Proizvodi i proizvodne tehnologije se brzo mijenjaju. Vremenska razdoblja između novih inovacija sve su kraća, što dovodi do smanjenja životnog vijeka proizvoda do 30 %, u posljednjih 10 godina. [6] Zbog kraćeg životnog vijeka proizvoda, kraćeg vremena na tržištu, te raznolike potrebe kupaca proizvođači nastoje poboljšati učinkovitost i produktivnost svojih proizvodnih djelatnosti. Kako bi to ostvarili proizvodni sustavi moraju biti u stanju proizvoditi proizvode visoke kvalitete u što kraćem vremenu te sa niskim troškovima proizvodnje. Osim toga proizvodni sustav bi trebao biti u mogućnosti prilagodbe i brze reakcije na promjene u dizajnu proizvoda i njegovih novih zahtjeva bez dodatnih većih ulaganja. [7]

Broj i kompleksnost proizvodnih varijanti raste. Kako bi ostale kompetentne, tvrtke se moraju prilagoditi promjenama tržišta. Glavni cilj svakog poduzeća je kvalitetan proizvod povoljne cijene izrađen u što kraćem roku. Za postizanje tih ciljeva na uravnotežen način, proizvodne tvrtke trebaju visoku fleksibilnost i visoku produktivnost u isto vrijeme. Ovo se posebno odnosi na tvrtke koje proizvode standardizirane dijelove. Često se ne obraća dovoljno pozornosti na analizu trenutne situacije u proizvodnji. [8] Ovakva situacija dovodi do potrebe za novim metodama planiranja proizvodnje. Klaster analiza, jedna od grupnih tehnologija, osim u područjima medicine, ekonomije, geografije i slično, primjenjuje se i u projektiranju proizvodnih sustava. Svrha primjene klaster analize u projektiranju proizvodnih sustava je oblikovanje skupina tehnološki sličnih dijelova i njima odgovarajućih skupina elemenata sustava (strojeva). Za primjenu klaster analize trebaju biti zadani skup dijelova i skup strojeva na kojima se dijelovi obrađuju, pri čemu je za svaki dio poznato na kojim se sve strojevima obrađuje. [1]

Kada se govori o strukturiranju proizvodnog sustava podrazumijeva se aktivnost kojoj je cilj najekonomičnije povezati i uskladiti konstituirajuće elemente u vremenu i prostoru. U ovom području svrha klaster analize je oblikovanje skupina tehnološki sličnih dijelova i njima

odgovarajućih skupina elemenata sustava (strojeva). Kako bi se provela klaster analiza trebaju biti zadani skup dijelova i skup strojeva na kojima se dijelovi obrađuju, pri čemu je za svaki dio poznato na kojim se sve strojevima obrađuje. Strojevi se tretiraju kao *obilježja* dijelova (objekata).


Naprimjer, automobil Volkswagen Golf sastoji se od 9890 komponenata. [8] Analiza tog proizvoda može biti vrlo kompleksna. Kako je svrha klaster analize otkrivanje strukture nekog početnog skupa podataka njegovim dekomponiranjem u manje, homogenije podskupove, ova metoda može se primjeniti i u navedenom primjeru. Multivarijantnost označava svojstvo klaster analize da više varijabli analizira istovremeno i zajedno kao dio jedne cjeline, što je važno u analizi proizvoda koji se sastoji od puno komponenata. Također, proizvodni sustavi u kojima se izrađuju proizvodi koji se sastoje od velikog broja dijelova, moraju biti projektirani na način da budu što efikasniji. Klaster analiza nalazi svoju primjenu i ovdje. Klaster analizom dobiju se skupine tehnološki sličnih dijelova koje pomažu u strukturiranju proizvodnog sustava. Sada je poznato koji se dijelovi mogu obrađivati na istom stroju. Tehnološki slični dijelovi proizvode se zajedno. Grupirajući slične dijelove može se projektirati proizvodni sustav koji će omogućiti smanjenje troškova tehnološke pripreme, bolje iskorištenje strojeva i opreme, jednostavnu raspodjela poslova, kratke transportne udaljenosti, velika preglednost procesa te jednostavno planiranje, vođenje i praćenje izradbe, uštedjeti zalihi materijala, skratiti vrijeme pripreme i slično, što je iznimno bitno za velike tvrtke kao što je Volkswagen. Automobilska industrija primjer je dobro strukturiranog proizvodnog sustava.

Efikasnost proizvodnoga sustava bitno ovisi o njegovoj prostornoj strukturi, jer ona izravno određuje sustav toka materijala koji se pak odražava na upravljivost proizvodnje, cikluse proizvodnje i iskorištenje sredstava za proizvodnju. Da se iskoriste prednosti serijske izradbe i u tvrtkama pojedinačne izradbe, 60-ih godina 20. stoljeća pojavila se ideja o grupnoj (skupnoj) tehnologiji. [1] Gordon M. Ransonu navodi da je skupna tehnologija „Logično grupiranje odnosno poredak operacija u svrhu poboljšanja produktivnosti naročito u masovnoj proizvodnji, te povećanje različitih proizvodnih količina.“ Primjenom skupne tehnologije identificiraju se i iskorištavaju sličnosti dijelova i sličnosti procesa izrade. Po konceptu skupne proizvodnje, pronalaženje tehnološki sličnih dijelova prvi je i nužan korak za oblikovanje i primjenu proizvodnih struktura zasnovanih po predmetnom načelu. Za definiranje skupina tehnološki sličnih dijelova primjenjuju se sljedeći posebni postupci:

analiza toka proizvodnje, sustavi klasifikacije i označavanja, te klaster analiza. [1] Želja za iskorištenjem prednosti masovne i velikoserijske proizvodnje u tvrtkama pojedinačne i maloserijske proizvodnje „smanjenje vremena za izradu tehnološkoga procesa izrade i modernizacija neki su od razloga uvođenja skupnih tehnologija.

Može se reći da se grupna tehnologija temelji na teoriji da „slične stvari treba izraditi na sličan način“. [7] U ovom kontekstu „stvari“ označavaju planiranje proizvoda, dizajn, izradu, montažu i kontrolu proizvodnje. Međutim, u širem smislu grupne tehnologije se mogu primjenjivati u svim aktivnostima uključujući i administrativne poslove. Princip grupne tehnologije je podijeliti proizvodni pogon u male skupine ili stanice strojeva.

Svaka stanica odnosno grupa posvećena je jednoj vrsti odnosno „familiji“ dijelova. U izradbenoj su stanici grupirani elementi u skladu s izradbenim procesom skupine tehnološki sličnih predmeta rada. Unutrašnja je struktura stanice slična podjeli po vrsti obrade, posjedujući fleksibilnost takve strukture, ali s prostornim rasporedom koji najbolje odgovara toku materijala izradbenoga procesa za definiranu grupu proizvoda. Ovakva struktura omogućava radnicima uvid u cjelokupni proizvodni proces. Strukturiranjem sustava na izradbene stanice dobiva se podjela na manje podsustave, pri čemu se značajno pojednostavnjuje sustav toka materijala, a time i planiranje te upravljanje proizvodnjom, stoga su posebno prikladne za primjenu koncepta skupne tehnologije. [1]



Slika 3. Grupiranje dijelova [10]

Kod negrupiranih dijelova teško je uočiti njihove tehnološke sličnosti te u kojoj mjeri bi se za njihovu izradbu mogli koristiti isti tehnološki procesi, stojevi i oprema. Kada su dijelovi grupirani, jasnije se vide zajednički procesi te se može razmišljati o skupinama alata i strojeva za svaku grupu dijelova. Klaster analiza pomaže formirati grupe sličnih dijelova. Grupiranje dijelova donosi brojne koristi u proizvodnji. Smanjuje broj i raznolikost dijelova, bolja je iskorištenost strojeva i opreme, pojednostavnjuje proces planiranja preostalih dijelova, daje bolju preglednost procesa, smanjuje se transport, omogućuje jednostavnost nadzora te veće uštede u zalihi materijala. Nekada grupna tehnologija uklanja i potrebu za skupom NC opremom. [10]

Osnovni ciljevi grupnih tehnologija, pa tako i same klaster analize jesu:

- dobro iskorištenje strojeva i opreme
- sniženje troškova tehnološke pripreme
- visoka produktivnost
- ubrzanje razvoja proizvoda
- omogućenje formiranja izradbenih stanica
- pojednostavljenje procesa planiranja
- smanjenje troškova alata
- uvođenje moderne proizvodne opreme
- pretvaranje niskoserijske u srednjeserijsku ili velikoserijsku
- odbacivanje neopravdane raznovrsnosti tehnoloških procesa unifikacijom i grupiranjem
- smanjenje vremena tehnološke pripreme za svaki član pripreme
- smanjenje transporta
- jednostavnost nadzora. [9]

Uštede grupnih tehnologija dolaze u mnogim oblicima, često nematerijalnim. Ovo su neka od poboljšanja koje su uspješni korisnici postigli:

- skraćeno vrijeme razvoja proizvoda preko 50%
- ušteda vremena rada inženjera preko 60%
- ušteda zalihe materijala cca 40 do 65 %
- skraćanje pripremno-završnih vremena, t_{pz} , 50 do 80 %
- ušteda vremena trajanja ciklusa proizvodnje, 40 do 80%
- ušteda troškova alata, do 40% [10]

4. KLASITERIRANJE KAO OBLIK TRŽIŠNOG POVEZIVANJA

Do sada je bila riječ o klaster analizi kao metodi grupiranja i klasificiranja u svrhu otkrivanja strukture nekog početnog skupa podataka te kao metoda u projektiranju proizvodnih sustava. Dakle bilo je riječ o numeričkoj metodi. Riječ klaster se može koristiti i u drugom kontekstu. U njemu je klaster koncept povezivanja poduzetnika unutar jednog industrijskog sektora, uz čvrstu suradnju sa znanstvenim i državnim ustanovama radi boljeg plasmana određene vrste proizvoda. Povezivanje obuhvaća sve segmente, od proizvodnje do marketinga i distribucije. Krajnji je cilj klastera da se preko mreže poslovno-inovacijskih središta stvore tržišni lideri. Time će se omogućiti ekspanzija izvoza, rasta i otvaranja novih radnih mjesta te umrežavanje i drugih poduzetnika u funkciji eksternoga rasta kroz konkurentnost. [11] Tvrtke se mogu udruživati u klastere zbog povećanja konkurentnosti domaćih proizvoda na domaćem i inozemnom tržištu, te boljeg korištenja domaćih resursa. Kroz klaster se može brže i jeftinije unaprijediti dizajn, uvesti nove tehnologije, brandirati proizvod te dobiti potrebne certifikate.

Kao primjer ovdje će se navesti ACH – Automobilski Cluster Hrvatske. Temeljem provedenih analiza ustanovljeno je da automobilsku industriju karakterizira rastuća globalizacija proizvodnje i intenzivan trend preseljenja pogona u tranzicijske i azijske zemlje. Stalni pritisak na snižavanje proizvodnih troškova te visoki tehnološki zahtjevi koje svjetski proizvođači automobila postavljaju pred proizvođače dijelova za autoindustriju onemogućavaju novim poduzećima ulazak, a postojećim opstanak na automobilskom tržištu. Inicijativa Istarske razvojne agencije i društva P. P.C. Buzet d.o.o. o osnivanju Automobilskog klastera Hrvatske proizašla je kao rješenje za svladavanje prepreka s kojima se suočavaju gospodarski subjekti koji direktno ili indirektno djeluju u sektoru automobilske industrije Hrvatske. Automobilski Cluster Hrvatske želi postati razvojno intenzivna i pouzdana mreža dobavljača za globalne proizvođače automobila u raznim segmentima, osiguravajući proizvode višeg stupnja kompleksnosti te veće dodane vrijednosti. [12] Neki od strateških ciljeva koji se žele postići udruživanjem u klaster jesu: jačanje konkurentskih

prednosti članica klastera te povećanje dodane vrijednost proizvoda, investirati u zaposlenike, njihovo osposobljavanje i edukaciju, što znači dostići najmanje 40 sati osposobljavanja i edukacije po zaposlenom godišnje, poticanje razvoja djelatnosti članica klastera i efikasnosti njihova poslovanja s adekvatnim istraživanjima u kooperaciji s ekspertima i znanstvenim institucijama u zemlji i inozemstvu.

5. SOFTVERI ZA KLASSTER ANALIZU

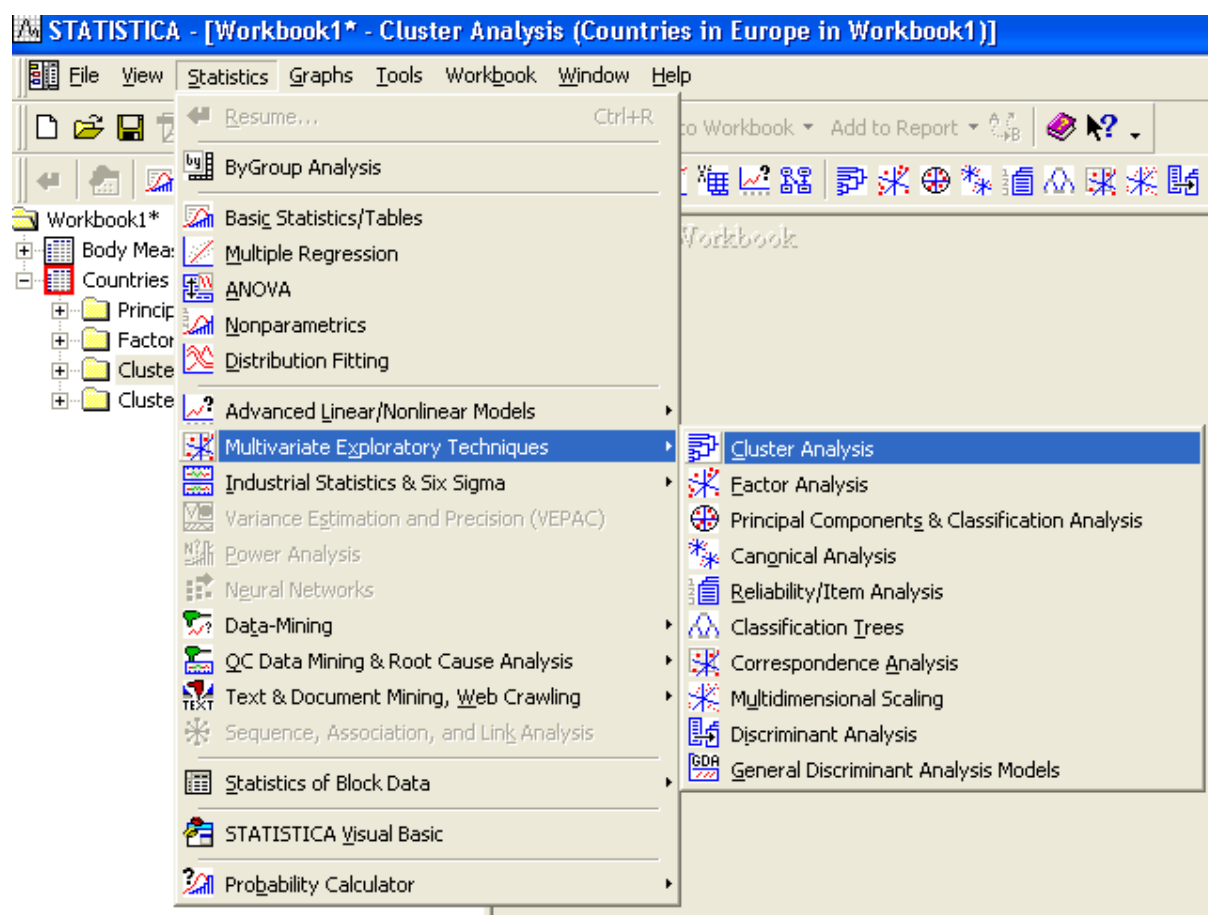
Postoje brojni softveri za provođenje klaster analize. IBM SPSS Statistics, Statistica, SAS neki su od najčešće korištenih softvera za provođenje klaster analize.

SPSS je programski paket koji se koristi za statističku analizu. Skraćenica SPSS izvorno je stajala iza naziva Statistical Package for the Social Sciences ,odnosno statistički paket za društvene znanosti. Danas je softver popularan i u drugim područjima uključujući ekonomiju, geografiju, medicinu, strojarstvo. Neke od statistika uključenih u bazu softvera su: deskriptivna statistika, *cluster* analiza, faktor analiza, linearna regresija. [13]

SAS (Statistical Analysis System) je softverski paket razvijen od strane SAS Instituta za napredne analize, multivarijatne analize, upravljanje podacima i analitiku. Riječ je o softverskom paketu koji može upravljati, mijenjati i dohvatiti podatke iz raznih izvora te na njima vršiti statističke analize. [14]

Nadalje , postoji niz malo manje poznatih softvera ali jednostavnih za korištenje kao što su PAST i Cluster 3.0. Radi se o besplatnima softverima, dostupnim svima. Njihovo sučelje jednostavno je za upotrebu. U radu bit će prikazan primjer klasteriranja u softveru PAST. Također provedba klaster analize bit će prikazana i računanjem funkcije cilja. Kako SPSS,SAS i STATISTICA nisu besplatni softveri, a ipak su jedni od najčešće korištenih , sučelje i princip rada jednog od njih bit će prikazano kroz slike dostupne na internetu.

Provedba klaster analize bit će ukratko objašnjena u programskom paketu STATISTICA. Pokretanje analize se vrši odabirom *Statistics* na glavnoj alatnoj traci. Nakon otvaranja prozora sa popisom statističkih tehnika odabire se *Multivariate Exploratory Techniques* gdje se naposljetku izabere *Cluster Analysis*. Na slici 4. prikazano je pokretanje klaster analize.



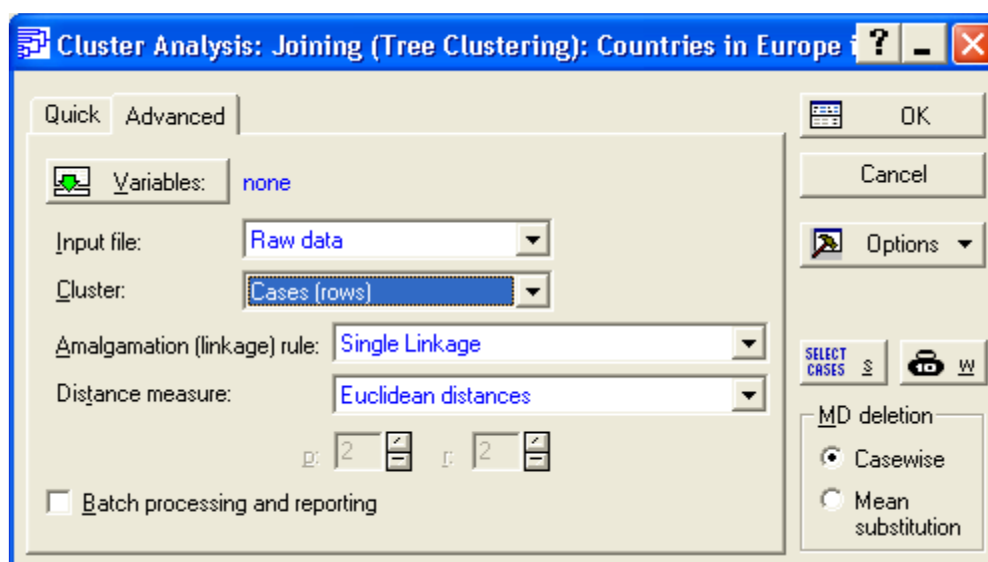
Slika 4. Početni izbornik za analizu [4]

Pokretanjem klaster analize otvara se izbornik u kojem se bira tip klaster analize.



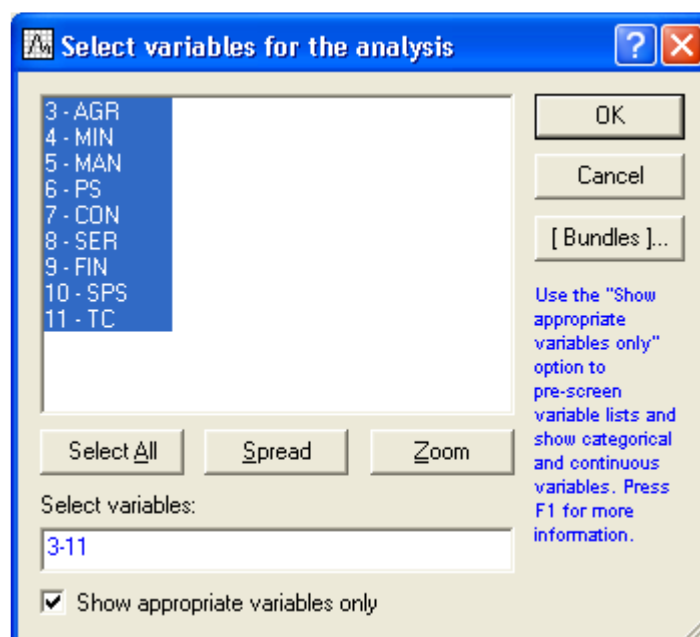
Slika 5. Odabir tipa klaster analize [4]

Pritiskom na „OK“ otvara se glavni izbornik za klaster analizu.

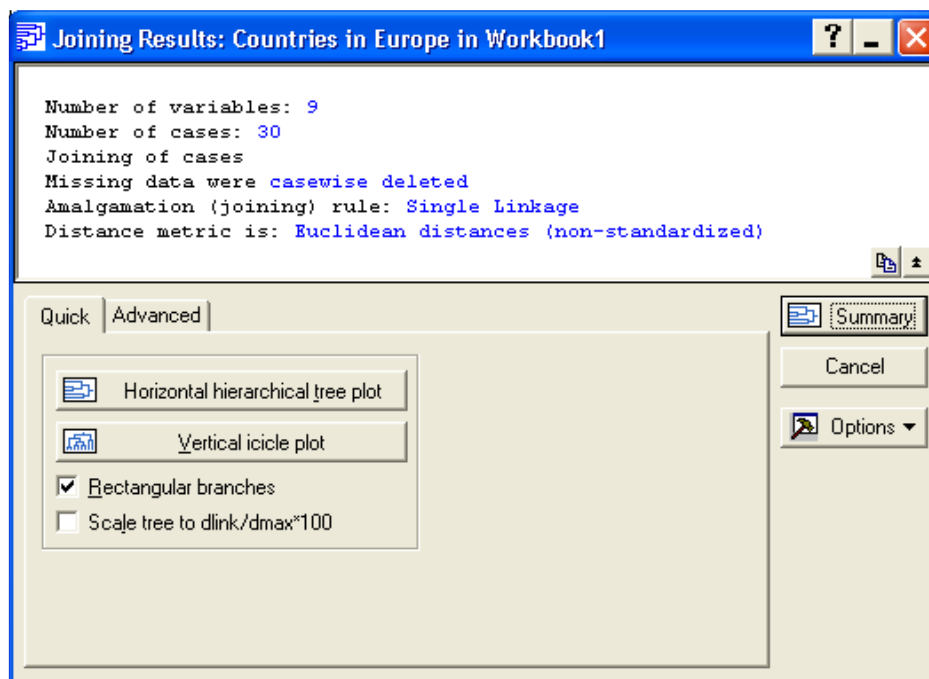


Slika 6. Kratki izbornik za klaster analizu [4]

U glavnom izborniku za klaster analizu potrebno je definirati opcije onako kako je prikazano na slici broj 6 (*Row data*; *Cases (rows)*; *Single Linkage*; *Euclidean distances*). Za definiranje varijabli nakon odabira brze (*Quick*) ili napredne (*Advanced*) analize, odabire se *Variables* te se otvara prozor sa popisom varijabli od kojih treba odabrati koje će biti uvrštene u analizu.




Slika 7. Izbor varijabli za analizu [4]



Slika 8 Prozor za brzu analizu [4]

Za izradu horizontalnog dendrograma odabire se *Horizontal hierarchical tree plot*. Postoji mogućnost izrade dendrograma i u vertikalnom smjeru za što se odabire *Vertical icicle plot*.



Slika 9. Dendrogram [4]

6. PRIMJER PROVEDBE KLASSTER ANALIZE BEZ UPOTREBE SOFTVERA

U ovom poglavlju će biti opisano provođenje klaster analize bez softvera, „ručno“, jednostavnog proizvodnog sustava koji se odnosi se na izradu 10 dijelova. Podaci iz ovog primjera bit će i softverski klasterirani.

Za svaki dio unaprijed je definiran tehnološki postupak obrade kao i strojevi na kojima se pojedine operacije obrade izvode. Dijelovi su preuzeti sa internetske stranice [15].

Tablica 3. Popis dijelova za klaster analizu

Redni broj	Naziv dijela	Oznaka
1.	Brtvena čahura KP4	4
2.	Kućište ležaja KP1	24
3.	Letva klizna KP1	32
4.	Osovina	41
5.	Poklopac ležaja (sa strane pumpe) KP4	54
6.	Rotor pumpe	65
7.	Držać navojnog vretena 250x5	74
8.	Navojno vreteno 630x8	86
9.	Vijak	100
10.	Vratilo KP5	106

Prije provođenja klaster analize kreira se binarna matrica dijelovi-strojevi, gdje vrijednosti polja matrice poprimaju vrijednosti 0 (i -ti dio se ne obrađuje na j -tom stroju) ili 1 (i -ti se dio obrađuje na j -tom stroju). Svaki je dio predstavljen odgovarajućim vektorom u m -dimenzionalnom prostoru. Binarna matrica prikazana je u tablici 4. Zatim se podijeli skup dijelova u nekoliko skupina. Za svaku je skupinu dijelova načinjena posebna tablica (tablica 5. i tablica 6.). Analizom tablica 5. i 6. uočava se podjela u dvije skupine. Za primjenu klaster

analize trebaju biti zadani skup dijelova i skup strojeva na kojima se dijelovi obrađuju, pri čemu je za svaki dio poznato na kojima se sve strojevima obrađuje.

Daljnja analiza strukture proizvodnog sustava provodi se pomoću klaster analize. Potrebno je izračunati mjere kompaktnosti pojedinih skupina dijelova i njihove funkcije cilja. Za svaku se skupinu dijelova načini posebna tablica (tablice 5 i 6).

Prvo je potrebno formirati binarnu matricu ($n \times m$, n dijelova, m strojeva). Zatim je potrebno definirati metriku za određivanje sličnosti (različitosti) dijelova, naprimjer euklidsku, koja se računa prema ispod navedenoj formuli.

$$d_{ij} = \left[\sum_{k=1}^m (x_{ik} - x_{jk})^2 \right]^{1/2}$$

pri čemu su:

x_{ik} – vrijednost k -tog obilježja i -toga dijela

x_{jk} – vrijednost k -tog obilježja j -toga dijela

m – broj obilježja (strojeva).

Zatim se određuje raspon broja skupina koje će se ispitivati. Raspon broja skupina određuje projektant prema vlastitoj procjeni. Za svaki se broj skupina unutar raspona generatorom slučajnih brojeva formira početno rješenje. Metodom premještanja, tj. prebacivanjem objekta iz skupine u skupinu, pokušava se poboljšati početno rješenje. Pri vrednovanju rješenja najčešće se rabi kriterij sume kvadrata odstupanja: što su točke u nekom podskupu prostora bliže jedna drugoj, suma kvadrata odstupanja bit će manja.

Za svako se j -to obilježje (od ukupno m obilježja) unutar svakog k -tog podskupa osnovnoga skupa računa aritmetička sredina

$$\bar{x}_{jk} = \frac{1}{n_k} \sum_{i=1}^{n_k} x_{ij} .$$

Potom se za svako obilježje podskupa sumiraju kvadrati odstupanja. Što je njihova suma manja, objekti su prema j -tom obilježju homogeniji:

$$O_{jk} = \sum_{i=1}^{n_k} (x_{ij} - \bar{x}_{jk})^2.$$

Sume kvadrata odstupanja svih m obilježja k -toga podskupa daje mjeru kompaktnosti skupine objekata:

$$O_k = \sum_{j=1}^m O_{jk}.$$

Funkcija cilja jest zbroj suma kvadrata odstupanja svih obilježja svih podskupova osnovnoga skupa S :

$$f_c = \sum_{k=1}^s O_k \rightarrow \min.$$

U tablici 4. (dana u dva dijela) vrijednosti polja matrice poprimaju vrijednosti 0 (i -ti dio se ne obrađuje na j -tom stroju) ili 1 (i -ti se dio obrađuje na j -tom stroju). Svaki je dio predstavljen odgovarajućim vektorom u m -dimenzionalnom prostoru.

Tablica 4. Binarna matrica dijelovi-strojevi

TOK2	TOK3	DUB	RM	GLO2	BURS	TOKR	TOK	BU,BUS	NAV16	PL	T2	BL	R1	RB
1	1	1	1	1	0	0	0	0	0	0	0	0	0	0
0	0			0	1	1	1	1	1	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	1	1	1	1
0	0	0	0	0	0	0	0	0	0	0	1	0	0	1
0	1	0	1	0	0	0	0	0	1	0	0	0	0	0
1	0	1	1	1	1	0	0	0	0	0	0	0	0	0
0	0	0	0	1	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
1	1			1	0	0	0	0	1	0	0	0	0	0

RB	T3	T1	G2	B1	BURS3	BUR	TOVA	GLO1	BRUP	PIL	PRN	GLO3	BRUP3
0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0
1	1	0	0	0	0	0	0	0	0	0	0	0	0
1	0	1	1	1	1	0	0	0	0	0	0	0	0
0	0	0	0	0	0	1	0	0	0	0	0	0	0
0	0	0	0	0	0	0	1	0	0	0	0	0	0
0	0	0	0	0	0	0	0	1	1	1	0	0	0
0	0	0	0	0	0	0	0	0	1	0	1	1	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	1	1

Tablica 5. Skupina dijelova C₁, m₁ = 4

	TOK2	TOK3	DUB	RM	GLO2	BURS	TOKR	TOK	BU,BUS	NAV16	PL	T2	BL	R1
41	0	0	0	0	0	0	0	0	0	0	1	0	0	0
65	1	0	1	1	1	0	0	0	0	0	0	0	0	0
86	0	0	0	0	0	0	0	1	0	0	0	0	0	0
106	1	1	0	1	0	0	0	0	0	1	0	0	0	0
Σ	2	1	1	2	1	0	0	1	0	1	1	0	0	0
\bar{x}_{ji}	0,5	0,25	0,25	0,5	0,25	0	0	0,25	0	0,25	0,25	0	0	0
41	0,25	0,0625	0,0625	0,25	0,0625	0	0	0,0625	0	0,0625	0,5625	0	0	0
65	0,25	0,0625	0,5625	0,25	0,5625	0	0	0,0625	0	0,0625	0,0625	0	0	0
86	0,25	0,0625	0,0625	0,25	0,0625	0	0	0,5625	0	0,0625	0,0625	0	0	0
106	0,25	0,5625	0,0625	0,25	0,0625	0	0	0,0625	0	0,5625	0,0625	0	0	0
O ₁₁	1	0,75	0,75	1	0,75	0	0	0,75	0	0,75	0,75	0	0	0
O ₁														14,75

R1	RB	T3	T1	G2	B1	BURS3	BUR	TOVA	GLO1	BRUP	PIL	PRN	GLO3	BRUP3
1	0	1	1	1	1	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	1	0	1	1	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	1	1
1	0	1	1	1	1	0	1	0	1	0	1	1	1	1
0,25	0	0,25	0,25	0,25	0,25	0	0,25	0	0,25	0	0,25	0,25	0,25	0,25
0,5625	0	0,5625	0,5625	0,5625	0,5625	0	0,0625	0	0,0625	0	0,0625	0,0625	0,0625	0,0625
0,0625	0	0,0625	0,0625	0,0625	0,0625	0	0,5625	0	0,0625	0	0,0625	0,0625	0,0625	0,0625
0,0625	0	0,0625	0,0625	0,0625	0,0625		0,0625	0	0,5625	0	0,5625	0,5625	0,0625	0,0625
0,0625	0	0,0625	0,0625	0,0625	0,0625	0	0,0625	0	0,0625	0	0,0625	0,0625	0,5625	0,5625
0,75	0	0,75	0,75	0,75	0,75	0	0,75	0	0,75	0	0,75	0,75	0,75	0,75

Tablica 6. Skupina dijelova C₂, m₂ = 6

	TOK2	TOK3	DUB	RM	GLO2	BURS	TOKR	TOK	BU,BUS	NAV16	PL	T2	BL	R1
4	1	1	1	1	0	0	0	0	0	0	0	0	0	0
24	0	0	0	0	1	1	1	1	1	1	1	0	0	0
32	0	0	0	0	0	0	0	0	0	0	0	1	1	1
54	0	1	0	1	0	0	0	0	0	0	1	0	0	0
74	0	0	0	1	0	0	0	0	0	0	0	0	0	0
100	0	0	0	0	0	0	0	0	0	0	0	0	1	0
Σ	1	2	1	3	1	1	1	1	1	1	2	1	2	1
\bar{x}_{j2}	0,166667	0,333333	0,166667	0,5	0,166667	0,166667	0,166667	0,166667	0,166667	0,333333	0,166667	0,333333	0,166667	
4	0,694444	0,444444	0,694444	0,25	0,027778	0,027778	0,027778	0,027778	0,027778	0,111111	0,027778	0,111111	0,027778	
24	0,027778	0,111111	0,027778	0,25	0,694444	0,694444	0,694444	0,694444	0,694444	0,444444	0,027778	0,111111	0,027778	
32	0,027778	0,111111	0,027778	0,25	0,027778	0,027778	0,027778	0,027778	0,027778	0,111111	0,694444	0,444444	0,694444	
54	0,027778	0,444444	0,027778	0,25	0,027778	0,027778	0,027778	0,027778	0,027778	0,444444	0,027778	0,111111	0,027778	
74	0,027778	0,111111	0,027778	0,25	0,027778	0,027778	0,027778	0,027778	0,027778	0,111111	0,027778	0,111111	0,027778	
100	0,027778	0,111111	0,027778	0,25	0,027778	0,027778	0,027778	0,027778	0,027778	0,111111	0,027778	0,444444	0,027778	
O_{j2}	0,833333	1,333333	0,833333	1,5	0,833333	0,833333	0,833333	0,833333	0,833333	1,333333	0,833333	1,333333	0,833333	
O_2														17,16

R1	RB	T3	T1	G2	B1	BURS3	BUR	TOVA	GLO1	BRUP	PIL	PRN	GLO3	BRUP3
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	1	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	1	1	1	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	1	0	0	0	0	0	1	0	1	1	1	0	0	0
0	0,166667	0	0	0	0	0,166667	0	0,166667	0,166667	0,166667	0	0	0	0
0	0,027778	0	0	0	0	0,027778	0	0,027778	0,027778	0,027778	0	0	0	0
0	0,027778	0	0	0	0	0,027778	0	0,027778	0,027778	0,027778	0	0	0	0
0	0,694444	0	0	0	0	0,027778	0	0,027778	0,027778	0,027778	0	0	0	0
0	0,027778	0	0	0	0	0,694444	0	0,027778	0,027778	0,027778	0	0	0	0
0	0,027778	0	0	0	0	0,027778	0	0,694444	0,694444	0,694444	0	0	0	0
0	0,027778	0	0	0	0	0,027778	0	0,027778	0,027778	0,027778	0	0	0	0
0	0,833333	0	0	0	0	0,833333	0	0,833333	0,833333	0,833333	0	0	0	0
17,16667														

Veličina O_{ij} jest suma kvadrata odstupanja prema težištu skupine, i mjera je kompaktnosti skupine.

Funkcija cilja računa se prema ispod danoj formuli.

$$f_{c_{stara}} = f_{c_{c1}} + f_{c_{c2}} = 14,75 + 17,667 = 32,417.$$

Dobivena funkcija cilja je 32,417. Cilj klaster analize je dobiti što nižu vrijednost funkcije cilja. Primjećuje se da je iznos funkcije cilja druge grupe prilično visok što ukazuje da je grupa prilično nehomogena. Ta će se vrijednost pokušati sniziti premještanjem jednog proizvoda iz grupe 2 u grupu 1. Brtvenu čahuru KP4 premješta se iz druge grupe u početnu grupu, te računa da li se iznos funkcije cilja smanjio. Promjenu funkcije cilja opisuje razlika Δ . Razlika Δ računa se slijedećom formulom.

$$\Delta = \frac{n_I}{n_I - 1} \left[\sum_{j=1}^m (x_j - \bar{x}_{jI})^2 \right] - \frac{n_D}{n_D + 1} \left[\sum_{j=1}^m (x_j - \bar{x}_{jD})^2 \right]$$

pri čemu su:

n_I – broj objekata skupine iz koje se izdvaja objekt

m – broj obilježja čitavog skupa

n_D – broj objekata skupine u koju se dodaje (premješta) objekt

x_{jI}, x_{jD} – aritmetičke sredine vrijednosti obilježja u podskupu iz kojega se izdvaja, odnosno u koji se dodaje objekt

x_j – vrijednost j -toga obilježja objekta koji se premješta.

Ukoliko je razlika Δ , dobivena prema gore navedenoj formuli veća od nule, premještanje se usvaja, u slučaju negativne vrijednosti razlike, premještanje se ne usvaja.

Nakon prebacivanja brtvene čahure KP4 (dio 4) iz skupine C_2 u skupinu C_1 dolazi se do zaključka. Budući da je razlika $\Delta = 1,117$, dakle veća od nule, premještanje se usvaja.

Nova funkcija cilja računa se po formuli:

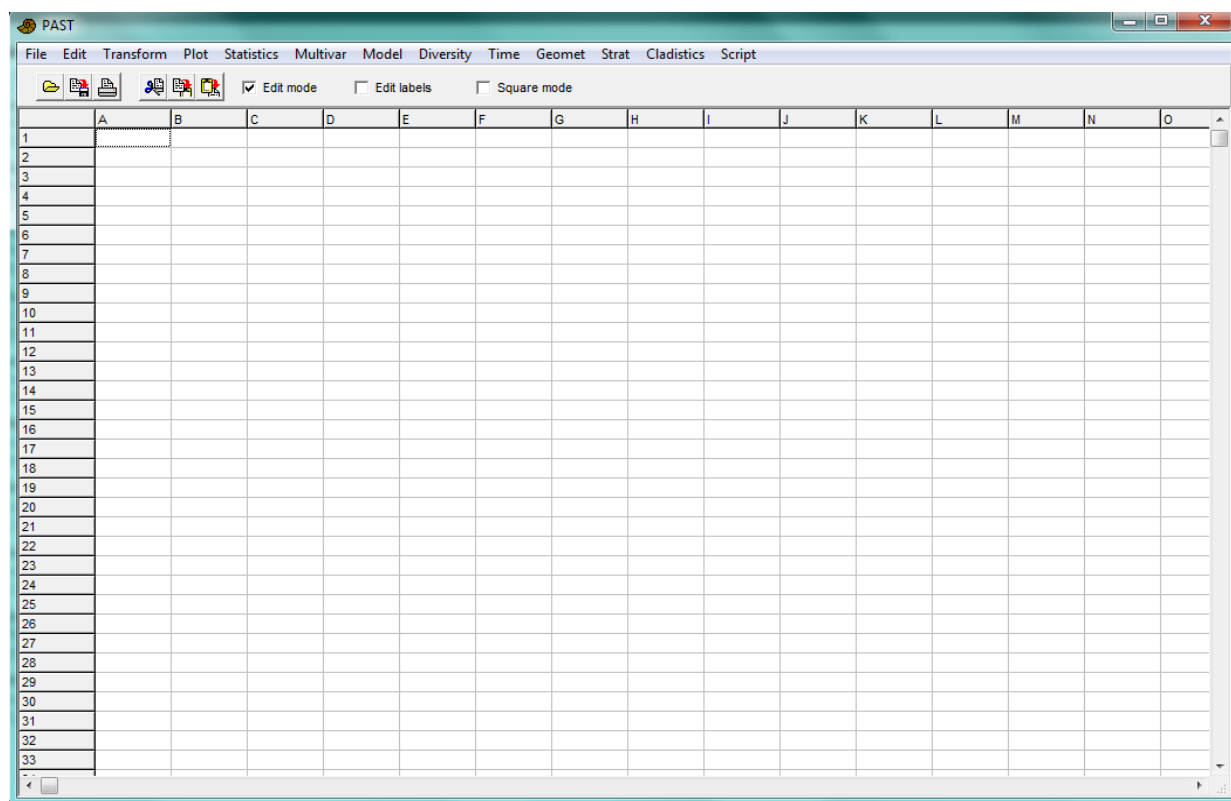
$$f_{C \text{ nova}} = f_{C \text{ stara}} - \Delta = 32,417 - 1,117 = 31,3.$$

Cilj klaster analize je dobiti što nižu vrijednost funkcije cilja. Postupak se ponavlja dok se ne dobije najniža moguća vrijednost funkcije cilja.

7. SOFTVER PAST

PAST je besplatan softver za analizu podataka, s funkcijama za manipulaciju podataka, crtanje, univarijatne i multivarijatne statistike. [15] PAST je praktičan alat osmišljen kako bi pomogao analizirati znanstvene podatke izračunavanjem statističkih pokazatelja. [16] Program dolazi s velikim raznim tehnikama analize lakim za korištenje.

Program se koristi za manipulaciju podataka s mogućnošću primjene različitih metoda analize. Jedna od njih je i *cluster* analiza. Podatci za analizu jednostavno se učitaju iz EXCEL-a ili tekstualne datoteke. Također postoji mogućnost kopiranja podataka iz druge aplikacije. Prije obrade podataka mogu se promijeniti naziv za svaki stupac i redak.

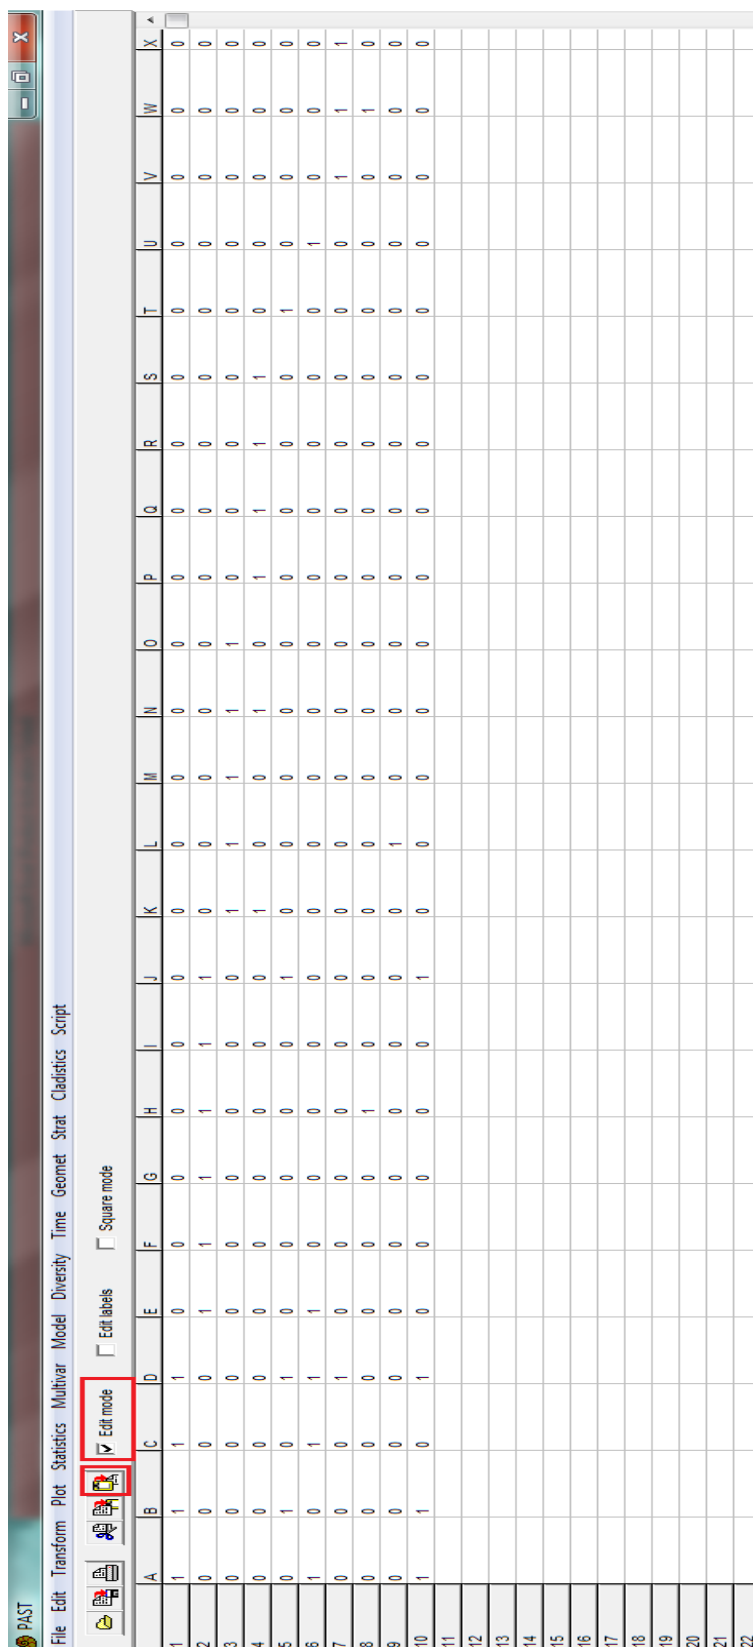


Slika 10. Glavni izbornik softvera PAST

Slika 10. prikazuje glavni izbornik PAST softvera. Za analizu bit će korišteni isti podatci kao u prethodnom primjeru, gdje smo klasteriranje provodili bez softvera, ručno. Dijelovi su preuzeti sa internetske stranice [15], te su dani u tablici 3.

U PAST softver kopirat će se podatci iz tablice 4. Treba se prisjetiti, da je riječ o tablici gdje vrijednosti polja matrice poprimaju vrijednosti 0 što znači da se i -ti dio se ne obrađuje na j -tom stroju ili 1 što predstavlja da se i -ti se dio obrađuje na j -tom stroju. Svaki je dio predstavljen odgovarajućim vektorom u m -dimenzionalnom prostoru.

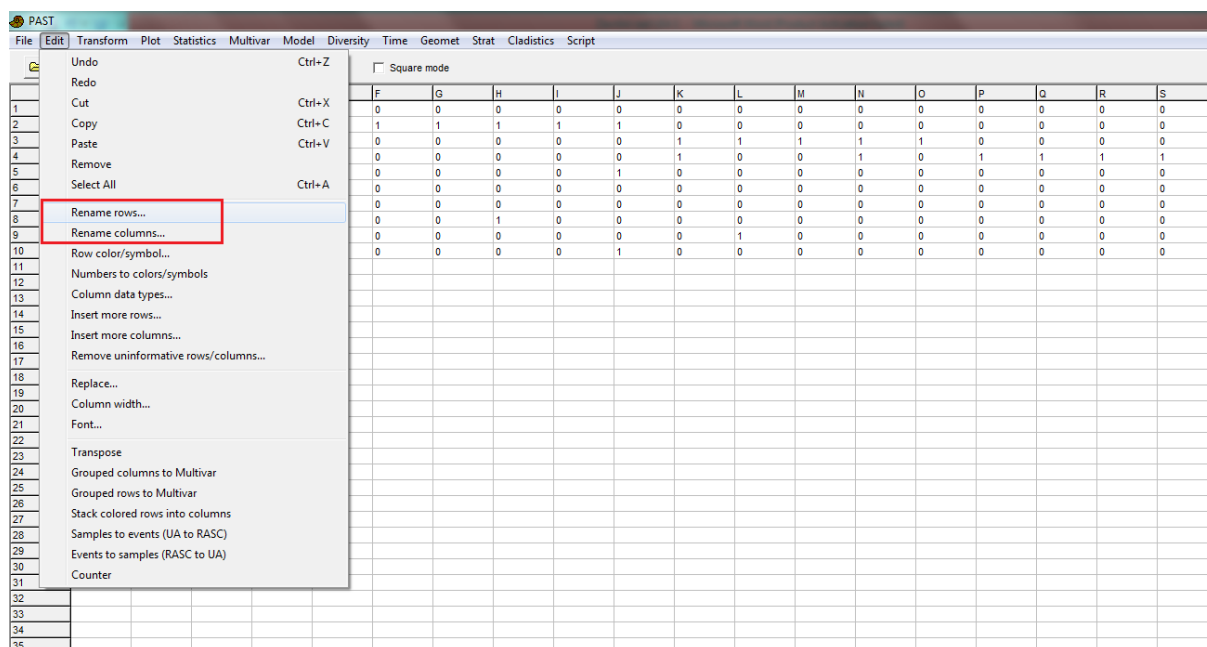
Nakon što se u EXCEL-u označi tablica koja se želi kopirati, odabirom ikone *Paste* unose se podatci u softver PAST. Ikona *paste* označena je crvenom bojom na slici 11. Također, važno je da prilikom unosa podataka i njihove obrade *Edit mode* bude označen kvačicom (označeno crvenom bojom na slici 11.). Nakon kopiranja binarne matrice izbornik sada izgleda kako je dano slikom 11.



Slika 11. Unos podataka


Kao što se vidi na slici 11., unijeti su samo podatci ali ne i nazivi strojeva i obrađivanih dijelova. Ukoliko se žele promijeniti nazivi redova i stupaca, odabire se na glavnoj alatnoj

traci *Edit*, a nakon toga *Edit Rows* i *Edit Columns*, kako je prikazano na slici 12. Redovi sadrže imena dijelova koji se obrađuju a stupci skraćenice strojeva (skraćenice strojeva u skladu su s onima danim u kolegiju *Projektiranje proizvodnih sustava*), preuzetih na internetskoj stranici [15]).

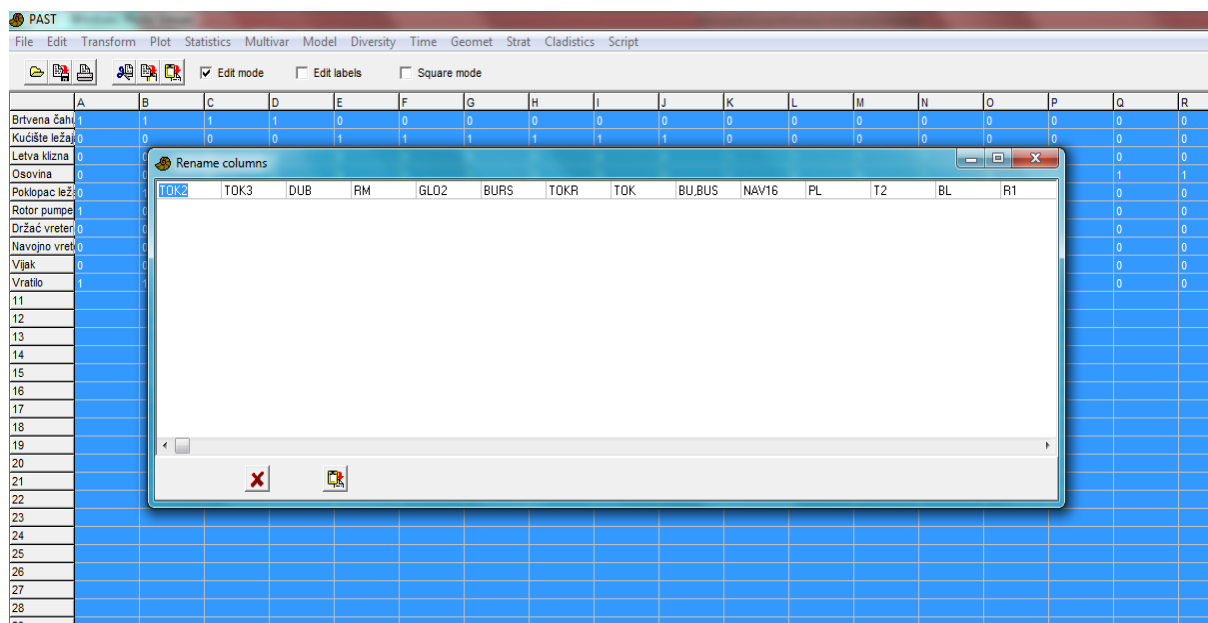


Slika 12. Promjena naziva stupaca i redaka

Na slici 13. prikazan je unos naziva dijelova koji se obrađuju. Prije nego se počnu unositi imena (*Rename rows* odnosno *Rename columns*), dobro je odabrati (zaplaviti) cijelu tablicu, jer na taj način se mogu u jednom koraku mijenjati nazivi redaka i stupaca. Inače se mora unositi naziv po naziv i postupak ponavljati za svaki redak odnosno stupac. Nakon unosa naziva redova samo se zatvori prozor za promjenu naziva. Na isti način se mijenjaju nazivi stupaca, samo umjesto. Tablica se opet u potpunosti označi (zaplavi) te se postupak ponovi.

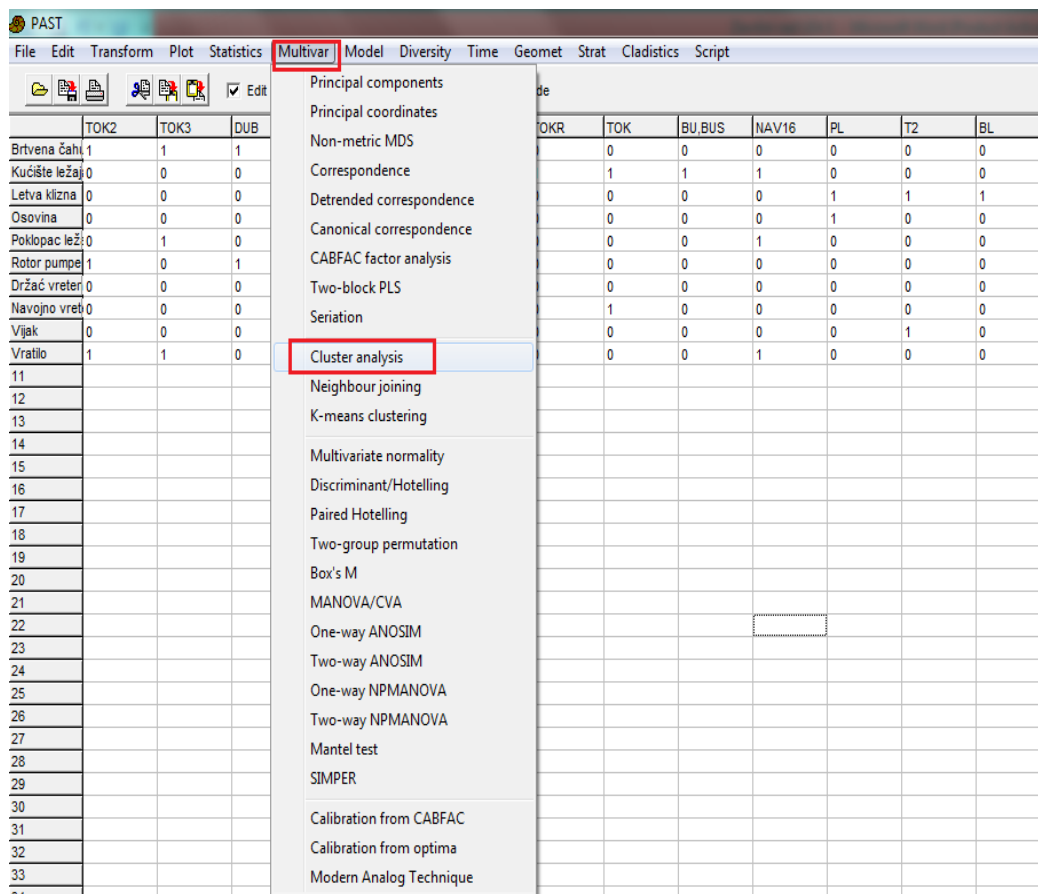


Slika 13. Unos naziva dijelova




Slika 14. Unos naziva strojeva

Nakon unosa podataka te naziva dijelova i strojeva, naša tablica je spremna za provedbu klaster analize. Na glavnoj alatnoj traci odaberemo *Multivar*, te nam se otvara popis multivarijantnih tehnika za analizu, odabiremo *Cluster analysis* kako je prikazano na slici 15.



Slika 15. Pokretanje softvera za klaster analizu

Nakon pokretanja klaster analize prikazuje nam se prozor prikazan na slici 16. Postoji mogućnost izbora mjere udaljenosti. Budući da je Euklidska mjera udaljenosti najčešća, te smo istu mjeru udaljenosti koristili u prethodnom primjeru, na popisu *Similarity measure* označi se *Euclidean*. Izbor mjere udaljenosti ovisi o istraživaču i mogu se izabrati i druge mjere udaljenosti.




Slika 16. Prozor softvera za klaster analizu

Kao konačni rezultat klaster analize dobiven je dendrogram. Dendrogram je grafički prikaz klastera u obliku stabla povezivanja. Prvo se vrše izračunavanja udaljenosti svih jedinica međusobno, a zatim se grupe formiraju putem tehnika spajanja. Dvije grupe se spajaju u jednu ukoliko je neka jedinica promatranja iz jedne grupe najbliža nekoj jedinici iz druge grupe.

Kako vidimo sa slike 16. na prvoj razini grupirani su redom, s lijeva na desno, klizna letva i vijak, navojno vreteno i držač navojnog vretena, poklopac ležaja i vratilo, rotor pumpe i brtvena čahura. Bliske grupe se postepeno spajaju dok se na kraju ne nađu sve jedinice u jednoj grupi.

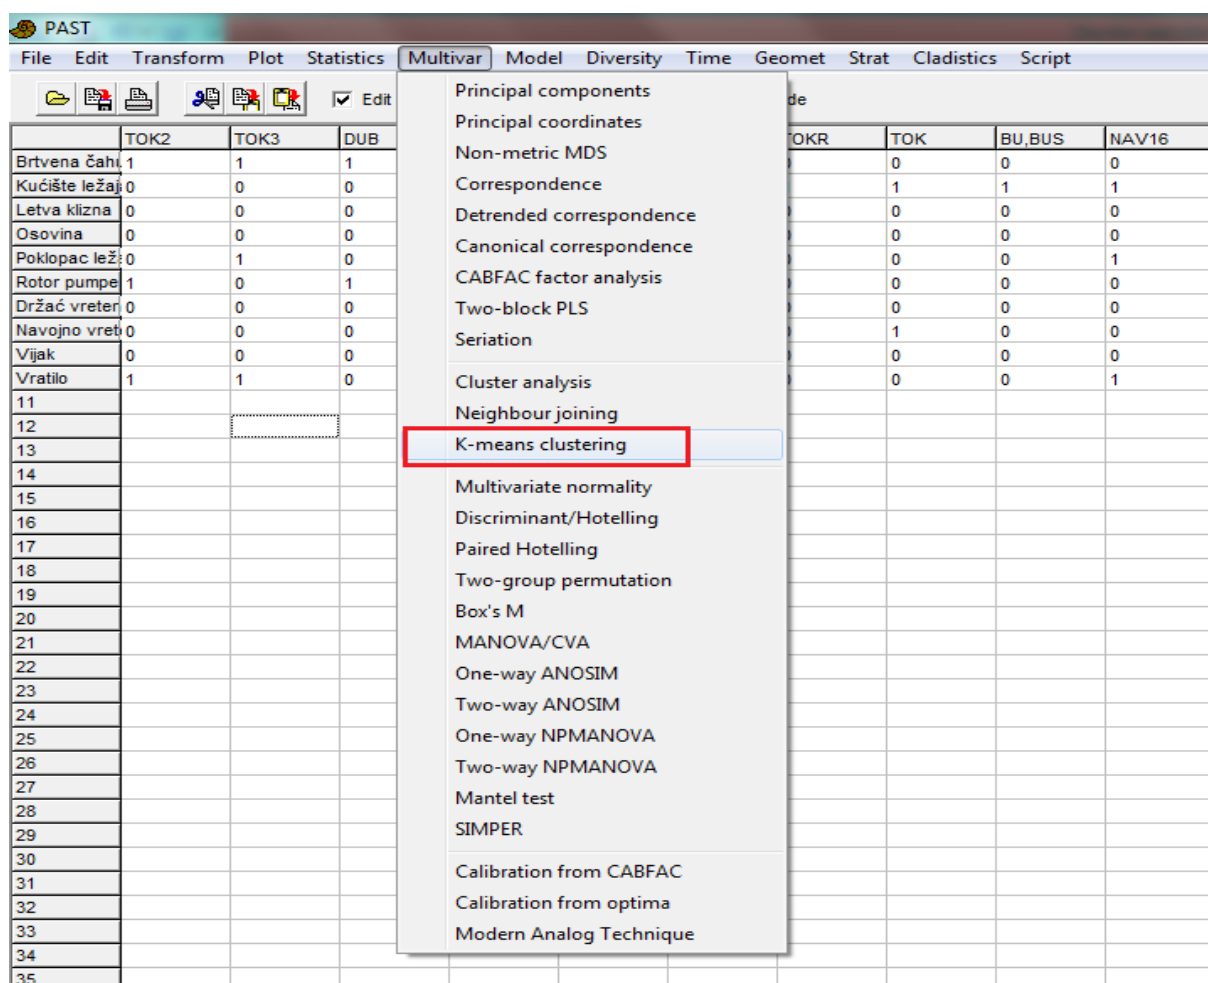
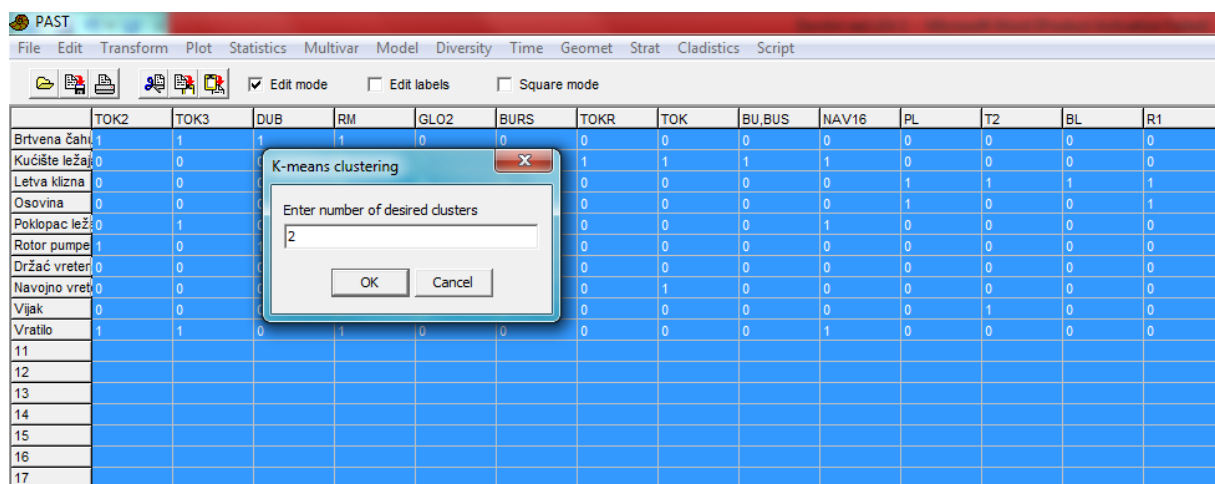
Također postoji i opcija dvosmjernog (*two-way*) prikaza dendrograma što je prikazano na slici 17. Takav način će osim dijelova grupirati i strojeve.



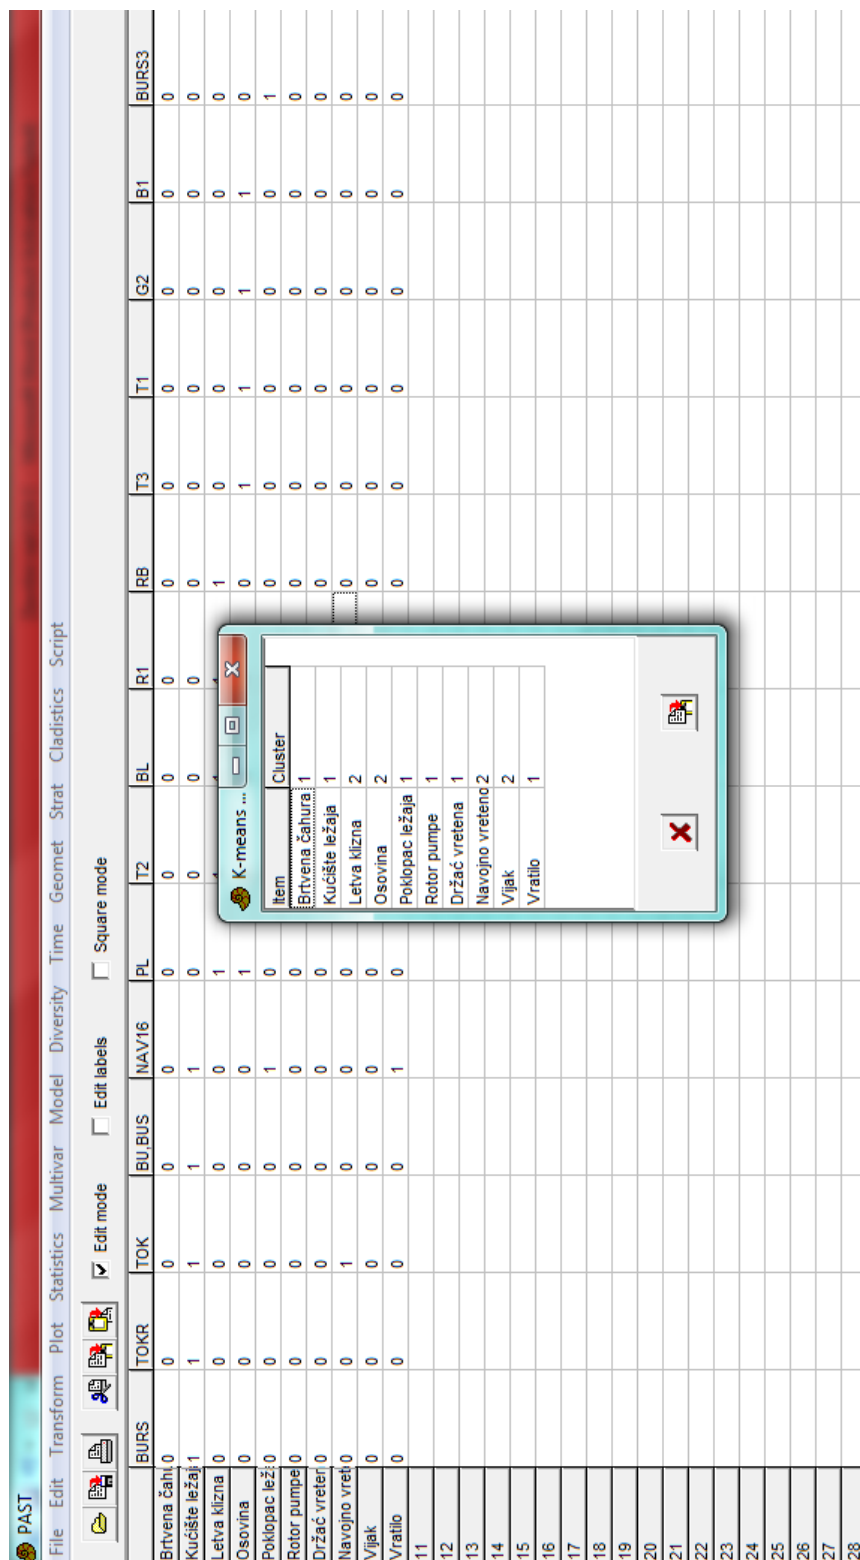
Slika 17. Dvosmjerni (*two-way*) dendrogram

Osim hijerarhijske metode klasteriranja gdje je konačni rezultat dendrogram Past ima mogućnost provedbe i nehijerarhijske metode koja se zove *k-means* metoda. Metoda *k-means* može se koristiti kao moguća potvrda hijerarhijskog postupka. Kod primjene *k-means* metode potrebno je unijeti broj klastera. Hijerarhijski pristup gradi klastere korak po korak, sve dok se sve jedinice promatranja ne nađu na dendrogramu. Tek nakon toga se pristupa određivanju broja klastera koji imaju značaj za istraživača. Nehijerarhijski pristup ili metoda raščlanjivanja polazi od unaprijed određenog broja klastera koji istraživač sam definira na osnovu iskustva, ranijih analiza ili preporuke statističkog softvera. Nakon toga se pristupa razvrstavanju jedinica promatranja. U ovom primjeru izabrana su dva klastera budući da u primjeru imamo samo deset dijelova za obradu. Provedba klaster analize primjenom metode *k-means* prikazana je na slici 18. Na glavnoj alatnoj traci odabiremo *Multivar* ali ovaj put na popisu analiza odabiremo *K-means clustering*. Nakon toga otvorit će se prozor gdje ćemo upisati broj klastera (Slika 19.).

Nakon unosa broja klastera kao rezultat *k-means* metode pojavljuje se tablica s dijelovima i njihovim pripadnostima određenoj grupi (Slika 20.).

Slika 18. Pokretanje *k-means* metode

Slika 19. Unos broja klastera

Slika 20. Rezultat *k-means* metode

K-means metoda grupirala je dijelove u dvije skupine. U skupini 1 nalazi se: brtvena čahura, kućište ležaja, poklopac ležaja, rotor pumpe, držać vretena te vratilo. U skupini 2 nalazi se:

letva klizna, osovina, navojno vreteno i vijak. Primjenom klaster analize dobili smo dvije skupine tehnološki sličnih dijelova. Sada je jasnije koji se dijelovi obrađuju na istim strojevima te se u skladu s time može projektirati efikasan proizvodni sustav.

U primjeru ručnog provođenja klasteriranja kao rezultat dobiveno je slijedeće:

- u prvoj skupini nalaze se brtvena čahura, osovina, rotor pumpe te navojno vreteno
- u drugoj skupini nalaze se kućište ležaja, klizna letva, poklopac ležaja, držač navojnog vretena i vratilo.

Ako se gornji rezultati usporede s rezultatima dobivenim softverom PAST, vidi se da oni donekle poklapaju. Razlog nepotpunog poklapanja rezultata leži u tome što ručno provođenje klasteriranja nije provedeno do kraja. Naime, radi primjera prikazano je samo jedno premještanje dijela iz jedne u drugu skupinu. Funkcija cilja bi se mogla dodatno smanjiti daljnjim premještanjem dijelova, a samim time bi se i rezultati bolje poklapali s onima dobivenima u softverskom klasteriranju.

Kao i svaka druga tehnika, i klaster analiza ima brojne prednosti i nedostatke. Zato je važno znati dobivene rezultate klasteriranja na odgovarajući način interpretirati te dovoljno poznavati teorijsku pozadinu istraživanja kako bi se dobiveni rezultati mogli iskoristiti za pronalaženje novih saznanja i spoznaja.

8. ZAKLJUČAK

U raznim područjima djelovanja, pa tako i u projektiranju proizvodnih sustava susreće se potreba grupiranja sličnih objekata iz neke veće cjeline u manje grupe na način da istoj grupi pripadaju objekti koji su po nekim svojstvima sličniji jedni drugima, a različitim grupama pripadaju elementi koji se međusobno znatno razlikuju. Upravo se time bavi klaster analiza. Njome se nastoji uspostaviti, ako je moguće, nezavisne skupine strojeva unutar kojih će se obrađivati skupine predmeta rada.

Primjena klaster analize u projektiranju proizvodnih sustava donosi brojne prednosti, a jedna od njih je mogućnost formiranja izradbenih stanica. U izradbenoj su stanici grupirani elementi u skladu s izradbenim procesom skupine tehnološki sličnih predmeta rada. Strukturiranjem sustava na izradbene stanice dobiva se podjela na manje podsustave, pri čemu se značajno pojednostavnjuje sustav toka materijala, a time i planiranje te upravljanje proizvodnjom. Ostale prednosti tako strukturiranih sustava jesu: dobro iskorištenje opreme i strojeva, jednostavna raspodjela poslova, kratke transportne udaljenosti, velika preglednost procesa te jednostavno planiranje, vođenje i praćenje izradbe.

U radu je istražena i zastupljenost softvera za klaster analizu. Najčešće korišteni softveri jesu: SPSS, Statistica, SAS. Također postoji i niz besplatnih softvera kao što su Past i Cluster 3.0. U radu je provedeno klasteriranje sa i bez softvera. Za softversko klasteriranje izabran je softver Past, čiji detaljni opis rada može služiti studentima kao i svima koji iz nekog razloga provode klaster analizu. Usporedbom rezultata klaster analize sa i bez softvera na primjeru 10 dijelova i 28 strojeva dolazi se do zaključka da dolazi do djelomičnog poklapanja rezultata, zbog ograničenja duljine postupka ručnog računanja.

Kao i svaka druga tehnika, tako i klaster analiza ima brojne prednosti i nedostatke koje svaki istraživač mora imati na umu, ukoliko ju primjenjuje. Također, važno je znati dobivene rezultate klaster analize na odgovarajući način interpretirati te dovoljno poznavati teorijsku

pozadinu istraživanja kako bi se dobiveni rezultati mogli iskoristiti za pronalaženje novih saznanja i spoznaja.

Iako se prvi oblici klaster analize javljaju još početkom prošlog stoljeća, još je mnogo neistraženih područja primjene. Naprimjer, klaster analiza bi se tako mogla koristiti i u razmatranju i realizaciji tržišnog povezivanja poduzeća što je u nas i u globaliziranom svijetu uvijek aktualno. Nadalje, premda je klaster analiza integrirana u komercijalnim softverima kao što su prije navedeni SAS i Statistica, nameće se i potreba razmatranja uključenja klaster analize u inženjerske softvere (npr. Catia).

9. LITERATURA

- [1] Kunica Z.: *Projektiranje proizvodnih sustava*, Predavanja iz kolegija, FSB, Zagreb, 2014.
- [2] https://en.wikipedia.org/wiki/Cluster_analysis, Pristupljeno: 2015-06-03
- [3] Nepoznati autor: *Primjena multivarijatnih metoda*, Predavanja iz kolegija, FFZG, Zagreb, godina nepoznata.
- [4] Nepoznati autor: *Multivarijantna statistička analiza*, Predavanja iz kolegija, Ekonomski fakultet, Subotica, 2015.
- [5] http://www.saedsayad.com/clustering_hierarchical.htm, Pristupljeno: 2015-06-15
- [6] Nachtwey A., Riedel R., Mueller E.: članak, *Cluster Analysis as a Method for the Planning of Production Systems*, Computers & Industrial Engineering, 2009.
- [7] Khanna K., Arneja G., Kumar R.: *Group Technology in Design of Manufacturing Systems*, Proceedings of the 5th International and 26th All India Manufacturing Technology, Design and Research Conference AIMTDR 2014, 2014.
- [8] <http://www.automobil.amag.ch/>, Pristupljeno: 2015-06-30
- [9] Ćosić P.: *Projektiranje tehnoloških procesa*, Predavanja iz kolegija, FSB, Zagreb, 2015.
- [10] http://www.strategosinc.com/group_technology.htm, Pristupljeno: 2015-07-14
- [11] www.limun.hr, Pristupljeno: 2015-08-05
- [12] www.ida.hr, Pristupljeno: 2015-08-05
- [13] <https://en.wikipedia.org/wiki/SPSS>, Pristupljeno: 2015-08-10
- [14] https://en.wikipedia.org/wiki/SAS_%28software%29, Pristupljeno: 2015-08-10
- [15] <http://titan.fsb.hr/~zkunica/pps/>, Pristupljeno: 2015-08-15
- [16] <http://folk.uio.no/ohammer/past/>, Pristupljeno: 2015-08-20
- [17] <http://www.softpedia.com/get/Science-CAD/PAST.shtml>, Pristupljeno: 2015-08-20